

基于长短期记忆网络的电网故障区域定位与故障传播路径推理

李舟平¹, 姚伟¹, 曾令康¹, 马士聪², 文劲宇¹

(1. 华中科技大学 电气与电子工程学院 强电磁工程与新技术国家重点实验室, 湖北 武汉 430074;

2. 中国电力科学研究院有限公司, 北京 100192)

摘要:为了在发生故障后维持电力系统的安全稳定,有必要实现对故障区域的快速定位并确定故障冲击的传播路径,提出基于长短期记忆网络(LSTM)的故障区域定位和故障传播路径推理方法。首先,利用LSTM建立2个故障诊断模型分别实现在线检测故障时刻和确定故障区域;然后,通过计算故障点附近线路的端口供给能量确定故障冲击的传播路径;最后,以8机36节点电网为例进行算例验证,结果表明所提模型可在发生故障后短时间内检测到故障,给出故障区域和故障冲击传播的路径,且对噪声有较强的鲁棒性。

关键词:电力系统;在线故障诊断;深度神经网络;长短期记忆网络;滑动窗口;端口供给能量

中图分类号:TM 72

文献标志码:A

DOI:10.16081/j.epae.202102016

0 引言

电力系统安全稳定运行与故障诊断密切相关。随着我国电网的发展,电网规模不断扩大并且结构日益复杂多样,这对电力系统故障诊断的实时性和准确性提出了更高的要求^[1]。在电力系统实际运行时,电力调度中心需要分析底层监测设备上传的数据和报警信息以快速准确地诊断电网故障、判断系统稳定性并及时采取适当的控制措施来维持系统稳定。因此,探究电网快速故障诊断和分析方案具有重要意义。

目前已有大量关于电网故障诊断的研究,主要方法有专家系统^[2]、贝叶斯网络^[3]、Petri网^[4-5]、模糊方法^[6-7]、人工神经网络^[8-10]、机器学习^[11]等。专家系统的诊断效果主要依赖知识库的完备性,而在复杂电网中构建完备的知识库相对困难。贝叶斯网络需要大量先验数据对节点赋值,且其应用于复杂电网时的训练属于非确定性多项式NP(Nondeterministic Polynomially)难题。Petri网在电网节点数多,在建模时容易出现信息组合爆炸的问题。上述方法大多使用保护元件动作的状态信息作为输入,但是复杂故障可能引起保护误动,从而影响故障诊断的准确性。

人工智能技术中以人工神经网络、机器学习方

法为代表的驱动方法在使用电气量输入进行故障诊断时具有较好的容错性和泛化能力,且在样本充足的情况下,理论上可以适应不同的电网规模。故障发生时区域内的电压均会下降,因此少量数据信息的丢失或误差对算法的影响较小。另外,数据驱动方法具有强大的非线性拟合能力,训练模型时使用各种工况下获得的样本,可以避免复杂的故障机理建模和分析。文献[8]基于人工神经网络实现电网故障检测和分类,使用小波变换辅助特征提取,但特征提取能力依赖于选取合适的小波族。文献[10]将保护和断路器状态作为输入,利用径向基函数神经网络实现故障诊断,具有训练速度快的优势,但输入数据中不包含不同时刻间的关联,可能难以有效处理复杂暂态时序特征。文献[11]利用匹配追踪分解算法进行故障特征提取,采用K-means算法对特征进行分类,然后通过隐马尔科夫模型实现故障诊断,在样本少时也能快速收敛,但对相量测量单元PMU(Phasor Measurement Unit)采样的频率要求较高,特征提取计算量较大,在线应用可能受限。故现有方法在提取输入中的复杂时序特征方面仍然存在不足。

长短期记忆网络LSTM(Long Short-Term Memory network)^[12]是一种具有记忆能力的神经网络,适合处理时序数据,已经广泛应用于语音识别^[13]、暂态功角稳定预测^[14]等领域。电力系统发生故障前、后的电气量数据存在比较复杂的时序关联特征,这些特征中包含了反映故障的信息。机器学习算法在输入的特征维度上难以体现时间关联,而LSTM能够分析时间序列输入并抽取重要的时序信息保存到记忆单元中,利用新的输入不断更新。故LSTM适合捕捉和提取故障前后的复杂时序特征和构建电网在线

收稿日期:2020-05-09;修回日期:2020-12-17

基金项目:国家电网有限公司科技项目(大型交直流混联电网故障特征深度学习及智能识别和控制应用研究)(SGHB0000KXJS1800375)

Project supported by the Science and Technology Program of SGCC(Research on Fault Characteristics Deep Learning and Intelligent Identification and Control Application of Large AC/DC Hybrid Grid)(SGHB0000KXJS1800375)

故障诊断模型。

基于此,本文提出一种基于LSTM的电网故障区域定位及故障传播路径推理方法。首先,通过广域测量系统WAMS(Wide Area Measurement System)采样获取输入节点电压,利用LSTM构建2个故障诊断模型分别用于确定故障时刻和故障区域;然后计算故障区域附近线路的端口供给能量ESP(Energy Supply on Port)并得到故障冲击的传播路径,为故障后施加强急控制措施的位置选择提供参考。以8机36节点电力系统为例验证了本文所提方法的有效性和噪声鲁棒性。

1 电网故障区域定位和故障传播路径推理

1.1 故障诊断和故障传播路径推理框架

为防止电网发生故障后事故扩大而影响系统安全稳定,调度中心通常需要在故障发生后的几百毫秒内迅速确定故障区域,并分析得出故障冲击在电网中传播的路径,以便后续紧急控制措施的制定。近年来,由于我国WAMS的广泛应用和PMU设备的大量部署^[15],实时获取大量节点的电气量测数据并基于数据驱动挖掘特征实现故障诊断成为可能。因此,本文构建的基于数据驱动的电网故障区域快速定位及故障传播路径推理框架如图1所示。整个框架分为3个模型,在每个采样时刻,首先获取WAMS采样数据并输入故障时刻判断模型以检测故障是否发生,若发生故障,则通过故障区域判断模型分析得出故障区域;待故障清除后通过传播路径推理模型计算该区域附近的故障冲击传播的路径;最后返回并重复在线故障诊断的流程。




图1 故障区域定位及故障传播路径推理框架

Fig.1 Framework of fault section location and propagation path reasoning

1.2 模型的滑动窗口输入

对于故障时刻判断模型和故障区域判断模型,每个采样时刻的输入是由WAMS采样并上传至调度中心的全网所有节点的电压幅值构成的矩阵 V ,如式(1)所示。

$$V = \begin{bmatrix} V_{1,1} & V_{1,2} & \cdots & V_{1,T} \\ V_{2,1} & V_{2,2} & \cdots & V_{2,T} \\ \vdots & \vdots & & \vdots \\ V_{N,1} & V_{N,2} & \cdots & V_{N,T} \end{bmatrix} \quad (1)$$

其中, $V_{m,n}$ ($m=1,2,\dots,N;n=1,2,\dots,T$)为节点 m 在第 n 个时刻的电压幅值; N 为全网节点总数; T 为时间长度。

模型的输入通过滑动窗口方式进行更新,如图2所示。由式(1)可将时刻 t_s 的输入矩阵按列分块记为 $V^{(s)}=[v_{s-T+1}, v_{s-T+2}, \dots, v_s]$;在下一时刻 t_{s+1} ,删去 $V^{(s)}$ 中的第1个元素 v_{s-T+1} ,并在其末端增加 v_{s+1} ,可得时刻 t_{s+1} 的输入为 $V^{(s+1)}=[v_{s-T+2}, v_{s-T+3}, \dots, v_{s+1}]$ 。




图2 滑动窗口输入的示意图

Fig.2 Schematic diagram of sliding window input

2 基于LSTM的电网故障区域定位和故障传播路径推理模型

图1中的故障时刻判断模型和故障区域判断模型可以由LSTM构建,LSTM的基本原理见附录A。

2.1 故障时刻判断模型

2.1.1 模型的输入、输出

故障时刻判断模型工作流程如图3所示,图中A表示LSTM。故障时刻判断模型获取时刻 t_i 滑动窗口截取的输入 $V^{(i)}$,经过z-score标准化预处理后进入




图3 故障时刻判断模型工作流程

Fig.3 Working flowchart of fault time judgment model

LSTM中进行计算。在 T 时刻堆叠的LSTM层提取输入中的时序特征得到输出 $\mathbf{h}_T$,然后通过全连接层将其映射为故障时刻判断向量 $\mathbf{M}^{(i)}=[m_1^{(i)}, m_2^{(i)}, \dots, m_T^{(i)}]$,其中 $\tau(\tau=1, 2, \dots, T)$ 时刻的分量 $m_\tau^{(i)}$ 为故障预判值。约定 $m_\tau^{(i)}=1$ 表示故障发生状态, $m_\tau^{(i)}=0$ 表示无故障状态。考虑到故障发生时刻会受噪声影响,故从故障开始时刻持续 a 个时刻将 $m_\tau^{(i)}$ 置1,其余元素置0。一般 a 可以根据实际测试情况选取,本文取 $a=3$ 。

2.1.2 输入标准化处理

在训练模型时,对于样本数量为 k 的样本集 $\{\mathbf{V}^{(1)}, \mathbf{V}^{(2)}, \dots, \mathbf{V}^{(k)}\}$,按照式(2)~(4)对样本集进行z-score标准化处理。

$$\mu_{m,n} = \frac{\sum_{i=1}^k V_{m,n}^{(i)}}{k} \quad (2)$$

$$\sigma_{m,n} = \sqrt{\frac{\sum_{i=1}^k (V_{m,n}^{(i)} - \mu_{m,n})^2}{k}} \quad (3)$$

$$X_{m,n}^{(i)} = \frac{V_{m,n}^{(i)} - \mu_{m,n}}{\sigma_{m,n}} \quad (4)$$

其中, $V_{m,n}^{(i)}$ 为样本 $\mathbf{V}^{(i)}$ 的第 m 行第 n 列元素; $X_{m,n}^{(i)}$ 为 $V_{m,n}^{(i)}$ 经过z-score标准化处理后的结果。

2.1.3 累计判断

为减少模型受到的干扰,提升模型判断故障的准确性和鲁棒性,本文设计累计判断的方式来判断故障发生时刻,如图4所示。在每一个采样时刻,神经网络输出一个判断向量 $\mathbf{M}^{(i)}$ 。将连续多个采样周期内模型输出的 $\mathbf{M}^{(i)}$ 中的最后一个分量 $m_T^{(i)}$ 与相应的采样时刻对齐。从时刻 t 至 t' ,累加每一时刻故障预判值 $m_{T-i+t}^{(i)}$ 可得故障判断累计次数 $K_t^{(i')}$,如式(5)所示。

$$K_t^{(i')} = \sum_{i=t}^{t'} m_{T-i+t}^{(i)} \quad (5)$$




图4 故障时刻判断向量与累计判断

Fig.4 Fault time judgment vector and cumulative judgment

设定 $K_t^{(i')}$ 的阈值为 K_0 。在时刻 t_d ,若检测到 $K_{t_d}^{(i')} \geq K_0$,则 t_d 为模型检测到故障的时刻, t'_d 为模型判断故障发生的时刻,并记实际故障发生时刻为 t_i ,保

存判断的故障时刻信息 t'_d 和 t_d ,将 $K_t^{(i')}$ 清零,启动故障区域判断模型;若检测到 $K_t^{(i')} < K_0$,则返回更新滑动窗口输入进行故障时刻判断。

2.2 故障区域判断模型

故障区域判断模型与故障时刻判断模型类似,也是对输入 $\mathbf{V}^{(i)}$ 经过z-score标准化处理后输入神经网络中,区别在于全连接层的输出为故障区域判断向量 $\mathbf{W}^{(i)}=[w_1, w_2, \dots, w_N]$ 。若电网中的节点 j 是故障的最邻近节点,则第 j 个元素 $w_j=1$,否则 $w_j=0$ 。假设一个电网的局部如图5中左侧部分所示,在节点 u 和节点 v 之间的线路发生故障,则模型输出 $\mathbf{W}^{(i)}$ 中有 $w_u=1, w_v=1$,其余元素为0,即此时故障的最邻近节点为节点 u 和节点 v 。




图5 故障最邻近节点及故障区域判断网络的输出示意图

Fig.5 Schematic diagram of nearest nodes around fault and output of fault section location model

输入 $\mathbf{V}$ 中若包含更多故障后的信息则有助于故障区域判断模型更加准确地判断故障区域。因此,在故障时刻判断模型确定故障发生时刻 t'_d 后,延迟 Δt_1 (Δt_1 为故障定位延迟时间),在时刻 $t'_d + \Delta t_1$ 采样 $\mathbf{V}$ 并进行标准化处理后输入故障区域判断模型中。

2.3 故障传播路径推理模型

电力系统在发生故障或受到扰动后,故障附近区域的电气量会发生较大的改变,扰动将以暂态能量的形式传播。由于故障位置、线路薄弱程度差异等因素,故障在系统中的传播路径和对各线路的冲击不同。判断出受扰动影响严重的区域和故障传播的路径,有利于后续确定控制措施的位置,增强系统第二道防线。

借助能量结构^[16],电力系统可表示成由端口互联子系统组成的物理系统^[17],故障冲击的传播体现在端口间的能量流动。因此,本文采用ESP^[17-18]进行故障传播路径推理。按式(6)计算支路 $i-j$ 上从节点 i 向节点 j 传播的ESP。

$$E_{ij}(t) = \int_0^t \left(\Delta P_{ij}(t) d\theta_i(t) + \frac{\Delta Q_{ij}(t)}{V_i(t)} dV_i(t) \right) = \int_0^t \left(2\pi \Delta P_{ij}(t) f_i(t) dt + \frac{\Delta Q_{ij}(t)}{V_i(t)} dV_i(t) \right) \quad (6)$$

$$\begin{cases} \Delta P_{ij}(t) = P_{ij}(t) - P_{ij}(t-1) \\ \Delta Q_{ij}(t) = Q_{ij}(t) - Q_{ij}(t-1) \end{cases} \quad (7)$$

其中, $E_{ij}(t)$ 为从节点 i 向节点 j 传播的 ESP; $P_{ij}(t)$ 、 $Q_{ij}(t)$ 分别为时刻 t 支路 $i-j$ 的有功和无功功率; $V_i(t)$ 、 $f_i(t)$ 、 $\theta_i(t)$ 分别为时刻 t 节点 i 的电压幅值、频率和相角。文献[19]指出由式(6)计算的能量与暂态能量是一致的,故 $E_{ij}(t)$ 反映了端口间暂态势能的转移和累积,可以表征故障对线路的冲击强度,其值越大说明线路受扰越严重,可作为施加后续控制措施位置的参考。根据 $E_{ij}(t)$ 的大小和正负可以判断系统短路故障的传播路径。

利用 ESP 推理故障传播路径,首先需要确定故障所在区域附近的线路,根据测量的节点电压幅值、相角和已知线路参数得到各条线路的传输功率,然后计算 $E_{ij}(t)$,按照 $E_{ij}(t)$ 的绝对值从大到小的顺序确定故障后冲击的传播路径,并结合 $E_{ij}(t)$ 的正负确定故障传播方向。

3 模型工作流程和样本生成

3.1 模型的工作流程

基于 LSTM 的电网故障区域判断及故障传播路径推理模型的工作流程如附录 B 图 B1 所示,具体步骤如下。

(1)构建样本生成数据库:由历史数据或者在多种工况下获得的仿真数据中的 V 构成样本生成数据库。

(2)生成模型样本集:用滑动窗口截取样本生成数据库中的样本以获取 2 个模型的样本集。

(3)设置训练参数:选择合适的神经网络超参数和阈值 K_0 、故障定位延迟时间 Δt_1 等模型辅助参数,然后重复训练和调整参数直至模型的性能达到最佳。

(4)故障时刻判断:滑动窗口截取当前时刻输入,启动故障时刻判断模型确定故障时刻。经过累计判定后,若确认故障发生则进入步骤(5),否则进入步骤(7)。

(5)故障区域判断:将延迟 Δt_1 后的输入数据输入故障区域判断模型中进行故障区域位置的判断,若故障已清除,则进入步骤(6),否则进入步骤(7)。

(6)故障传播路径推理:启动故障传播推理模型计算 ESP,获得故障发生后传播的路径。

(7)输出与更新滑动窗口:输出当前的故障诊断信息,增加新采样的数据并更新滑动窗口,返回步骤(4),循环诊断故障。

3.2 样本生成数据库

算例使用 8 机 36 节点电力系统,系统接线图见

附录 C 图 C1。为了训练 2 个基于 LSTM 的故障诊断模型,首先在各种工况下通过时域仿真生成时间序列,构成样本生成数据库。本文的仿真工况包括短路故障工况和发生负荷小扰动的无故障工况,2 种工况下的扰动时刻均设置为 0.5 s,其他仿真工况的具体设置见附录 C 表 C1。最后一共获得 1 215 个故障时间序列和 350 个无故障时间序列。仿真时长为 2 s,电气量的采样频率按照 WAMS 上传帧率的国际标准 IEEE C37.118.1—2011^[20]设为 50 帧/s,即周期为 20 ms。

3.3 样本集生成

不同模型所需的样本集不同,样本集生成示意图见附录 C 图 C2。故障时刻判断模型需要在滑动窗口的任意时刻都能判断故障发生时刻,同时能够准确区分故障和小扰动。因此,从数据库中依次抽取时间序列,用滑动窗口随机截取(需包含故障或扰动时刻)多次获得故障时刻判断模型的样本集,样本标签按 2.1.1 节的约定设置。

故障区域判断模型的输入为故障发生后延迟 Δt_1 的采样输入。利用滑动窗口依次对数据库中短路故障工况下的时间序列截取固定时刻获得样本集,样本标签按照 2.2 节的约定设置。考虑到故障时刻判断模型判断的故障时刻存在较小的误差 ε ,因此故障后的延迟时间可调整为 $\Delta t_1 \pm \varepsilon$ 。

为了模拟模型在线故障诊断,利用滑动窗口按采样间隔依次截取样本生成数据库中的时间序列作为模型在线应用时的输入。

4 算例验证

4.1 模型的训练

随机打乱故障时刻判断模型和故障区域判断模型各自的样本集,然后按 4:1 的比例分成训练集和测试集。2 个模型均采用 Adam 学习算法进行训练,学习率为 0.000 1,设定二元交叉熵作为损失函数,将准确率作为训练指标。故障时刻判断模型训练 600 轮后收敛,故障区域判断模型训练 300 轮后收敛。

4.2 模型的性能测试

4.2.1 性能指标和噪声设置

(1)故障检测时间误差 Δt_f :故障时刻判断模型判断的故障发生时刻 t'_f 与实际故障时刻 t_f 的差,即 $\Delta t_f = t'_f - t_f$ 。

(2)故障检测时间延迟 Δt_d :故障时刻判断模型实际检测到故障的时刻 t_d 和实际故障时刻 t_f 的差,即 $\Delta t_d = t_d - t_f$ 。

(3)故障区域定位准确率:准确给出故障附近最邻近节点的样本占测试样本的比例。

(4)噪声设置:为测试噪声强度对 2 个模型性能指标的影响,在 2 个模型的样本集中分别加入一定

信噪比 SNR(Signal to Noise Ratio)的高斯白噪声, SNR按照式(8)进行计算。

$$\lambda_{\text{SNR}} = 20 \lg \frac{A_s}{A_n} \quad (8)$$

其中, λ_{SNR} 为 SNR 的值; A_s 、 A_n 分别为信号和噪声的幅值。

4.2.2 性能测试、分析和对比

(1) 故障检测测试。

使用故障时刻判断模型的测试集对模型进行测试可得混淆矩阵如表 1 所示, 可见该模型能够准确区分故障和非故障样本。

表 1 故障检测的混淆矩阵


判断结果	实际情况		总计
	实际有故障	实际无故障	
判定有故障	972	0	972
判定无故障	0	280	280
总计	972	280	1252

(2) 故障检测时间误差测试。


按照 3.3 节所述方式获取在线故障诊断的样本, 并依次测试在 2 个模型的样本集中加入 λ_{SNR} 为 40、35、30 dB 的噪声。统计不同 λ_{SNR} 下的故障检测时间误差 Δt_f 的分布如图 6(a) 所示。图中, 横坐标为对应变量与周期的比值, 图 6(b)、7 中同。由图可见, 当 $\lambda_{\text{SNR}} > 30$ dB 时, 90% 以上的 Δt_f 均为 0, 几乎所有样本的 $|\Delta t_f|$ 都在 2 个周期以内。这表明本文所提方法的故障检测时间误差在 2 个周期以内, 具有较强的噪声鲁棒性。

(3) 故障检测时间延迟。

对故障检测时间误差测试中的故障检测时间延



(a) 故障检测时间误差的分布



(b) 故障检测时间延迟的分布

□ 无噪声, □ $\lambda_{\text{SNR}} = 40$ dB
□ $\lambda_{\text{SNR}} = 35$ dB, □ $\lambda_{\text{SNR}} = 30$ dB

图 6 不同噪声强度下故障检测时间误差和延迟的分布

Fig.6 Distribution of fault detection time error and delay under different noise intensities

迟 Δt_d 进行统计, 结果如图 6(b) 所示。由图可以看出, 几乎所有的 Δt_d 均为 3~4 个周期, 这表明本文所提方法在故障发生后的 3~4 个周期内即可准确检测出故障。

(4) 故障区域定位准确率测试。

在完成故障检测时间误差测试和故障检测时间延迟统计的基础上, 进行故障区域定位准确率测试。不同 K_0 和 λ_{SNR} 下的故障区域定位准确率如表 2 所示。由表可见, 当 $\lambda_{\text{SNR}} = 40$ dB 时故障区域定位准确率在 97% 以上, $\lambda_{\text{SNR}} = 30$ dB 时故障区域定位准确率仍有 95%。使用累计判断方法并适当增大 K_0 可提高故障时刻判断的精度, 但是当 K_0 过大时, 故障区域定位准确率提升有限(见表 2 中加粗数据), 而 Δt_d 会增大从而影响故障检测速度, 所以应用模型时需要合理地选择 K_0 。

表 2 故障区域定位准确率

K_0	故障区域定位准确率 / %			
	无噪声	$\lambda_{\text{SNR}} = 40$ dB	$\lambda_{\text{SNR}} = 35$ dB	$\lambda_{\text{SNR}} = 30$ dB
1	99.59	97.94	96.71	95.06
2	99.59	98.77	97.12	95.06
3	99.59	98.77	97.12	95.47

(5) 故障定位延迟时间测试。

设置不同的 Δt_l 和 λ_{SNR} , 统计对应的故障区域定位准确率如图 7 所示。由图可知, 当 Δt_l 较大时, 故障区域定位准确率才比较高, 而 Δt_l 越大, 故障定位时间越长, 但故障区域定位准确率并不会有明显提升, 故选择合适的延迟 Δt_l 才能在故障发生后较短时间内实现准确率较高的定位效果, 本文取 $\Delta t_l = 10$ 。




图 7 故障定位延迟时间对故障区域定位准确率的影响

Fig.7 Influence of fault location delay time on accuracy of fault section location

(6) 与其他机器学习算法的比较。

本文所提基于 LSTM 的方法与典型的机器学习算法的对比结果如表 3 所示。由表可见, 虽然决策树(DT)和随机森林(RF)算法在存在一定噪声时仍具有较高的准确率, 但是低于本文所提方法的准确率; 普通多层神经网络(ANN)的噪声鲁棒性较差, 在实际应用中会受到限制。因此, 本文所提基于 LSTM 的方法能够快速准确地定位故障区域, 且相比于典

型机器学习算法具有较强的噪声鲁棒性。

表3 与经典机器学习算法的对比

Table 3 Comparison with typical machine learning algorithms

算法	故障区域定位准确率 / %			
	无噪声	$\lambda_{\text{SNR}}=40 \text{ dB}$	$\lambda_{\text{SNR}}=35 \text{ dB}$	$\lambda_{\text{SNR}}=30 \text{ dB}$
ANN	99.59	87.08	83.95	80.00
DT	99.34	94.49	90.78	81.32
RF	99.42	95.97	92.18	89.63
LSTM	99.59	98.77	97.12	95.47

(7)模型诊断速度分析。

在电网实际故障诊断中,通常需要考虑量测信息获取、通信、处理等方面的延时问题。本文选择WAMS采样的电气量数据作为输入,正常通信延时在15 ms以内,根据上述测试结果可知,在70~75 ms内可以实现故障的准确检测,在160~200 ms内可实现故障区域定位。另外,本文方法使用的LSTM和ESP的计算以线性计算为主,计算效率高,在调度中心配备高性能计算机的情况下所需的数据处理时间较短。因此,本文方法基本满足实际调度中心的需求。

4.3 故障传播路径推理

按照2.4节计算在线路9-23故障和线路25-26故障这2种工况下各线路的ESP(ESP为标么值,后同),结果分别见图8和附录C图C3。图中,通过线路的线条粗细和颜色深浅表征 $E_{ij}(t)$ 的大小,即线路受故障冲击程度,颜色越深、线条越粗,冲击越大;线路上的箭头代表故障冲击的传播方向,由 $E_{ij}(t)$ 的符号决定。将线路的 $E_{ij}(t)$ 的大小按降序排列,选取部分ESP值较大的线路列在表4、5中。

图8对应的工况为线路9-23中部在0.5 s时发生三相短路故障并在0.6 s时清除故障。由图可见,




图8 线路9-23故障后系统的ESP分布

Fig.8 Distribution of ESP in power grid after failure of Line 9-23

表4 线路9-23故障清除瞬间,部分线路的ESP值

Table 4 ESP of several branches at moment that fault of Line 9-23 is cleared

线路	故障清除后 ESP	线路	故障清除后 ESP
9-23	8.4677	12-26	0.7894
2-9	8.3488	23-24	0.7341
1-24	1.9230		

表5 线路25-26故障清除瞬间,部分线路的ESP值

Table 5 ESP of several branches at moment that fault of Line 25-26 is cleared

线路	故障清除后 ESP	线路	故障清除后 ESP
25-26	1.6259	12-15	1.0114
11-25	1.3862	14-15	1.0114
12-26	1.3287	9-10	0.9081
14-19	1.0289	10-11	0.9081

故障线路9-23紧邻发电机,故障冲击产生的能量几乎全部直接流向变压器支路2-9进入发电机节点2,仅有少部分流向线路1-24进入发电机1,其他各线路受到故障冲击的影响较小。附录C图C3对应的工况为线路25-26中部在0.5 s时发生三相短路故障并在0.6 s时清除故障。由图可见,故障冲击分别沿线路11-25、12-26等传播。此时由于故障线路与发电机相隔较远,故障产生的冲击沿着相邻线路四处扩散。

在发生故障后,故障冲击会在故障周边区域扩散,离故障越远的线路的ESP值越小,即所受的冲击小,因而控制措施在故障传播的区域附近实施可能会更有效。另外,根据故障冲击的分散性可以合理选择控制措施的位置和控制量。

5 结论

(1)针对电网快速故障诊断的需求,本文利用人工智能深度学习技术进行了初步探索,构建了基于LSTM的电网故障在线诊断模型,该模型可以提取WAMS采样数据中的时序关联特征,实现故障时刻和故障区域的判断,且不依赖于故障机理建模和分析。算例分析结果表明,与典型的机器学习算法相比,本文方法的诊断准确率更高,且具有较好的噪声鲁棒性。

(2)使用滑动窗口可以实现在线故障检测,采用累计判定的方式有助于提升故障时刻判断模型的准确率。故障区域判断模型可以在满足区域定位的速度要求的前提下灵活权衡模型诊断速度和准确率,利用故障后延迟采样的数据作为输入可提升模型准确率。

(3)故障判断网络确定了故障所在区域后,通过计算故障清除时刻线路的端口供给能量并排序,进而得出故障传播的路径,有利于后续采取控制措施

位置的确定。

附录见本刊网络版(<http://www.epae.cn>)。

参考文献:

- [1] 王家林,夏立,吴正国,等. 电力系统故障诊断研究现状与展望[J]. 电力系统保护与控制,2010,38(18):210-216.
WANG Jialin,XIA Li,WU Zhengguo,et al. State of arts of fault diagnosis of power systems[J]. Power System Protection and Control,2010,38(18):210-216.
- [2] BERNARD J,DUROCHER D. An expert system for fault diagnosis integrated in existing SCADA systems[J]. IEEE Transactions on Power Systems,1994,9(1):548-554.
- [3] 罗孝辉,童晓阳. 计及可信度的变结构贝叶斯网络电网故障诊断[J]. 电网技术,2015,39(9):2658-2664.
LUO Xiaohui,TONG Xiaoyang. Structure-variable Bayesian network for power system fault diagnosis considering credibility[J]. Power System Technology,2015,39(9):2658-2664.
- [4] 徐彪,尹项根,张哲,等. 计及拓扑结构的时间Petri网故障诊断模型[J]. 中国电机工程学报,2019,39(9):2723-2734.
XU Biao,YIN Xianggen,ZHANG Zhe,et al. Time Petri net based fault diagnosis model considering topology structure[J]. Proceedings of the CSEE,2019,39(9):2723-2734.
- [5] 赖宏毅,汪畅,杨雯,等. 基于事件起点的层次化时序Petri网及其电网故障诊断方法[J]. 电力自动化设备,2018,38(2):201-209.
LAI Hongyi,WANG Yang,YANG Wen,et al. Hierarchical temporal Petri net based on event-starting point and its fault diagnosis method of power grid[J]. Electric Power Automation Equipment,2018,38(2):201-209.
- [6] CHIN H C. Fault section diagnosis of power system using fuzzy logic[J]. IEEE Transactions on Power Systems,2003,18(1):245-250.
- [7] 何俊涛,车仁飞,孟庆萌,等. 基于广域录波数据和FCM聚类的电网故障诊断方法[J]. 电力自动化设备,2019,39(6):179-184.
HE Juntao,CHE Renfei,MENG Qingmeng,et al. Fault diagnosis method of power grid based on wide-area recorder data and fuzzy C-means clustering[J]. Electric Power Automation Equipment,2019,39(6):179-184.
- [8] SILVA K M,SOUZA B A,BRITO N S D. Fault detection and classification in transmission lines based on wavelet transform and ANN[J]. IEEE Transactions on Power Delivery,2006,21(4):2058-2063.
- [9] YU J J Q,HOU Y H,LAM A Y S,et al. Intelligent fault detection scheme for microgrids with wavelet-based deep neural networks[J]. IEEE Transactions on Smart Grid,2019,10(2):1694-1703.
- [10] 毕天姝,倪以信,吴复立,等. 基于新型神经网络的电网故障诊断方法[J]. 中国电机工程学报,2002,22(2):73-78.
BI Tianshu,NI Yixin,WU Fuli,et al. A novel neural network approach for fault section estimation[J]. Proceedings of the CSEE,2002,22(2):73-78.
- [11] 施微,黄磊,徐箭,等. 基于有限同步量测数据的电力系统故障检测、辨识与定位[J]. 电网技术,2015,39(4):1067-1074.
SHI Wei,HUANG Lei,XU Jian,et al. Fault detection,identification and location based on measurement data from finite synchronized phasor measurement[J]. Power System Technology,2015,39(4):1067-1074.
- [12] HOCHREITER S,SCHMUDHUBER J. Long short-term memory[J]. Neural Computation,1997,9(8):1735-1780.
- [13] GRAVES A,MOHAMED A,HINTON G. Speech recognition with deep recurrent neural networks[C]//IEEE International Conference on Acoustics,Speech and Signal Processing. Vancouver,Canada:IEEE,2013:6645-6649.
- [14] 刘俐,李勇,曹一家,等. 基于支持向量机和长短期记忆网络的暂态功角稳定预测方法[J]. 电力自动化设备,2020,40(2):129-136.
LIU Li,LI Yong,CAO Yijia,et al. Transient rotor angle stability prediction method based on SVM and LSTM network[J]. Electric Power Automation Equipment,2020,40(2):129-136.
- [15] 段刚,严亚勤,谢晓冬,等. 广域相量测量技术发展现状与展望[J]. 电力系统自动化,2015,39(1):73-80.
DUAN Gang,YAN Yaqin,XIE Xiaodong,et al. Development status quo and tendency of wide area phasor measuring technology[J]. Automation of Electric Power Systems,2015,39(1):73-80.
- [16] 李颖,沈沉,刘锋. 基于能量结构的电力系统振荡分析方法[J]. 电力系统自动化,2013,37(13):49-56.
LI Ying,SHEN Chen,LIU Feng. A methodology for power system oscillation analysis based on energy structure[J]. Automation of Electric Power Systems,2013,37(13):49-56.
- [17] 汤蕾,沈沉,王志文,等. 基于端口供给能量的特高压电网扰动冲击传播机理分析[J]. 高电压技术,2015,41(3):824-831.
TANG Lei,SHEN Chen,WANG Zhiwen,et al. Mechanism of disturbance impact propagation in ultra-high voltage power system based on energy supply on port[J]. High Voltage Engineering,2015,41(3):824-831.
- [18] 代贤忠,沈沉. 基于端口供给能量分解的电力系统振荡类型区分方法[J]. 电力系统自动化,2014,38(23):40-45.
DAI Xianzhong,SHEN Chen. A power system oscillation property identifying method based on decomposition of energy supply on port[J]. Automation of Electric Power Systems,2014,38(23):40-45.
- [19] 陈磊,闵勇,胡伟. 基于振荡能量的低频振荡分析与振荡源定位(一)理论基础与能量流计算[J]. 电力系统自动化,2012,36(3):22-27.
CHEN Lei,MIN Yong,HU Wei. Low frequency oscillation analysis and oscillation source location based on oscillation energy part one mathematical foundation and energy flow computation[J]. Automation of Electric Power Systems,2012,36(3):22-27.
- [20] Power System Relaying Committee. IEEE standard for synchrophasor measurements for power systems;IEEE C37.118.1-2011[S]. New York,USA:IEEE Standard Association,2011.

作者简介:



李舟平

李舟平(1997—),男,湖北鄂州人,硕士研究生,主要研究方向为人工智能在大电网稳定分析中的应用(E-mail: lizp_hust@163.com);

姚伟(1983—),男,湖北浠水人,教授,博士研究生导师,博士,通信作者,主要研究方向为电力稳定分析与控制、柔性直流输电系统及其控制、风力发电系统的非线性控制(E-mail: w.yao@hust.edu.cn)。

(编辑 任思思)

(下转第178页 continued on page 178)

Adaptive relay protocol for power line-wireless hybrid media communication system

SHI Yanping^{1,2}, WANG Lijiao³, LI Xiucui¹, LI Lang¹, HUANG Xin^{1,2}, CHEN Zhixiong³

(1. NARI Group Corporation / State Grid Electric Power Research Institute, Nanjing 211006, China;

2. State Key Laboratory of Smart Grid Protection and Control(NARI Group Corporation), Nanjing 211106, China;

3. Department of Electronic and Communication, North China Electric Power University, Baoding 071003, China)

Abstract: Considering hybrid media communication and relay cooperative technology, the wireless mobile access, wireless and power line parallel transmission systems are studied. By using multidimensional LogN approximation algorithm and MGF(Moment Generating Function) of terminal SNR(Signal to Noise Ratio), the closed analytic expressions of the outage probability when the system adopts AF(Amplify and Forward) and DF(Decode and Forward) are deduced respectively. Then, in order to overcome the shortcomings of AF and DF relay protocols effectively, the adaptive relay protocol is proposed, that is, AF or DF relay protocols are dynamically selected according to the channel communication quality. The specific implementation steps are given. Monte Carlo simulation is used to verify the effectiveness and reliability of theoretical analysis, and the theoretical and simulative results show that, compared with AF and DF relay protocols, the proposed adaptive relay protocol can achieve better communication quality in both low and high SNR regions.

Key words: hybrid media communication; power line communication; wireless communication; diversity and combining; adaptive relay protocol; multi-dimensional LogN approximation algorithm; performance analysis

(上接第170页 continued from page 170)

Fault section location and fault propagation path reasoning of power grid based on LSTM

LI Zhouping¹, YAO Wei¹, ZENG Linggang¹, MA Shicong², WEN Jinyu¹

(1. State Key Laboratory of Advanced Electromagnetic Engineering and Technology, School of Electrical and Electronic Engineering, Huazhong University of Science and Technology, Wuhan 430074, China;

2. China Electric Power Research Institute, Beijing 100192, China)

Abstract: To maintain the security and stability of power system after failure, it is necessary to locate the fault section quickly and determine the propagation path of the fault impact, a fault section location and fault propagation path reasoning method based on LSTM(Long Short-Term Memory network) is proposed. Firstly, two fault diagnosis models are built by LSTM to realize online fault time judgment and fault section location respectively. Then, the propagation path of the impact caused by the fault can be determined by the ESP(Energy Supply on Port) of the transmission lines near the fault. Finally, the 8-machine 36-bus power grid is taken as an example for verification, and the results show that the proposed model can detect the fault immediately after it occurs, give fault section and fault impact propagation path, and has strong robustness to noise.

Key words: electric power systems; online fault diagnosis; deep neural network; long short-term memory network; sliding window; energy supply on port

附录 A：LSTM原理简介

LSTM 与普通神经网络的差别在于 LSTM 神经元中存在记忆单元。图 A1 为 1 个 LSTM 神经元的结构。在 t 时刻，LSTM 的输入为 x_t ，状态为 C_t ，输出为 h_t ；LSTM 有 3 个门控，其中输入门实现输入 x_t 选择性更新状态 C_t ，遗忘门实现状态 C_t 选择性遗忘，输出门实现状态 C_t 选择性输出 h_t 。门控量 i_t 、 f_t 、 o_t 按式 (A1) 计算：

$$\begin{cases} i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \\ f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \\ o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \end{cases} \quad (A1)$$

其中， W_i 、 W_f 、 W_o 为各门控的权重矩阵； b_i 、 b_f 、 b_o 为各门控的偏置向量； $[h_{t-1}, x_t]$ 为 h_{t-1} 和 x_t 拼接的向量； σ 表示激活函数 sigmoid；“ $\cdot$ ”表示矩阵乘法运算。

在 t 时刻，按式 (A2) 计算输入门输入 c_t' ；状态 C_t 由 C_{t-1} 经过遗忘门后选择性保留的部分和 c_t' 经过输入门后选择性接受的部分组成，按式 (A3) 计算；输出 h_t 按式 (A4) 计算。

$$c_t' = \tanh(W_c \cdot [h_{t-1}, x_t]) \quad (A2)$$

$$C_t = f_t * C_{t-1} + i_t * c_t' \quad (A3)$$

$$h_t = o_t * \tanh(C_t) \quad (A4)$$

其中， $\tanh$ 为激活函数；“ $*$ ”表示张量元素积运算。




图 A1 LSTM 神经元的结构

Fig.A1 Structure of a LSTM neuron

附录 B：故障区域定位及故障传播路径推理流程




图 B1 故障区域定位及故障传播路径推理流程

Fig.B1 Flowchart of fault section location and propagation path reasoning

附录 C：算例验证设置和结果




图 C1 8 机 36 节点系统接线图

Fig.C1 Wiring diagram of 8-machine 36-node system

表 C1 样本生成数据库的时域仿真设置

Table C1 Time domain simulation configurations for sample generation database

故障工况			无故障工况		
类型	具体设置	数量	类型	具体设置	数量
故障类型	三相短路接地故障	1	潮流变化	1.15, 1.1, 1.0, 0.9, 0.8	5
故障线路	所有交流线路	27	负荷波动	所有负荷	10
故障位置	10%, 20%, 30%, ..., 90%	9	波动幅度	25%, 15%, 5%, 0%, -5%, -15%, -25%	7
潮流变化	1.15, 1.1, 1.0, 0.9, 0.8	5			




图 C2 故障时刻判断和故障区域判断模型的样本生成

Fig.C2 Sample generation for fault time judgment model and fault section location model




图 C3 线路 25-26 故障后系统的 ESP 分布

Fig.C3 ESP distribution of power grid after failure of line 25-26